32 | Window操作&Watermark：流处理引擎提供了哪些优秀机制？

2021-11-24 吴磊

《零基础入门Spark》 课程介绍 >

讲述：吴磊
时长 18:12 大小 16.68M

你好，我是吴磊。

在上一讲，我们从原理的角度出发，学习了 Structured Streaming 的计算模型与容错机制。深入理解这些基本原理，会帮我们开发流处理应用打下坚实的基础。

在“流动的 Word Count”那一讲，我们演示了在 Structured Streaming 框架下，如何做流处理开发的一般流程。基于 readStream API 与 writeStream API，我们可以像读写 DataFrame 那样，轻松地从 Source 获取数据流，并把处理过的数据写入 Sink。

今天这一讲，咱们从功能的视角出发，继续来聊一聊 Structured Streaming 流处理引擎都为开发者都提供了哪些特性与能力，让你更灵活地设计并实现流处理应用。

Structured Streaming 怎样坐享其成？

学习过计算模型之后，我们知道，不管是 Batch mode 的多个 Micro-batch、多个作业的执行方式，还是 Continuous mode 下的一个 Long running job，这些作业的执行计划，最终都会交付给 Spark SQL 与 Spark Core 付诸优化与执行。

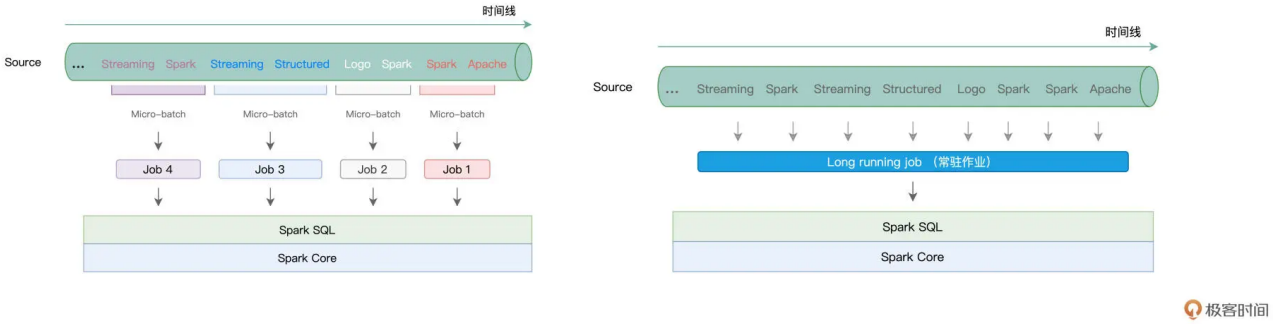

两种计算模型的执行方式

而这，会带来两个方面的收益。一方面，凡是 Spark SQL 支持的开发能力，不论是丰富的 DataFrame 算子，还是灵活的 SQL 查询，Structured Streaming 引擎都可以拿来即用。基于之前学过的内容，我们可以像处理普通的 DataFrame 那样，对基于流数据构建的 DataFrame 做各式各样的转换与聚合。

另一方面，既然开发入口同为 DataFrame，那么流处理应用同样能够享有 Spark SQL 提供的“性能红利”。在 Spark SQL 学习模块，我们学习过 Catalyst 优化器与 Tungsten，这两个组件会对用户代码做高度优化，从而提升应用的执行性能。

因此，就框架的功能来说，我们可以简单地概括为，Spark SQL 所拥有的能力，Structured Streaming 都有。不过，除了基本的数据处理能力以外，为了更好地支持流计算场景，Structured Streaming 引擎还提供了一些专门针对流处理的计算能力，比如说 Window 操作、Watermark 与延迟数据处理，等等。

Window 操作

我们先来说说 Window 操作，它指的是，Structured Streaming 引擎会基于一定的时间窗口，对数据流中的消息进行消费并处理。这是什么意思呢？首先，我们需要了解两个基本概念：Event Time 和 Processing Time，也即事件时间和处理时间。

所谓事件时间，它指的是消息生成的时间，比如，我们在 netcat 中敲入“Apache Spark”的时间戳是“2021-10-01 09:30:00”，那么这个时间，就是消息“Apache Spark”的事件时间。

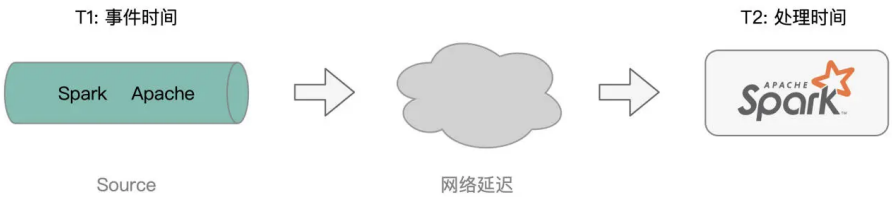

事件时间与处理时间

而处理时间，它指的是，这个消息到达 Structured Streaming 引擎的时间，因此也有人把处理时间称作是到达时间（Arrival Time），也即消息到达流处理系统的时间。显然，处理时间要滞后于事件时间。

所谓 Window 操作，实际上就是 Structured Streaming 引擎基于事件时间或是处理时间，以固定间隔划定时间窗口，然后以窗口为粒度处理消息。在窗口的划分上，Structured Streaming 支持两种划分方式，一种叫做 Tumbling Window，另一种叫做 Sliding Window。

我们可以用一句话来记住二者之间的区别，Tumbling Window 划分出来的时间窗口“不重不漏”，而 Sliding Window 划分出来的窗口，可能会重叠、也可能会有遗漏，如下图所示。

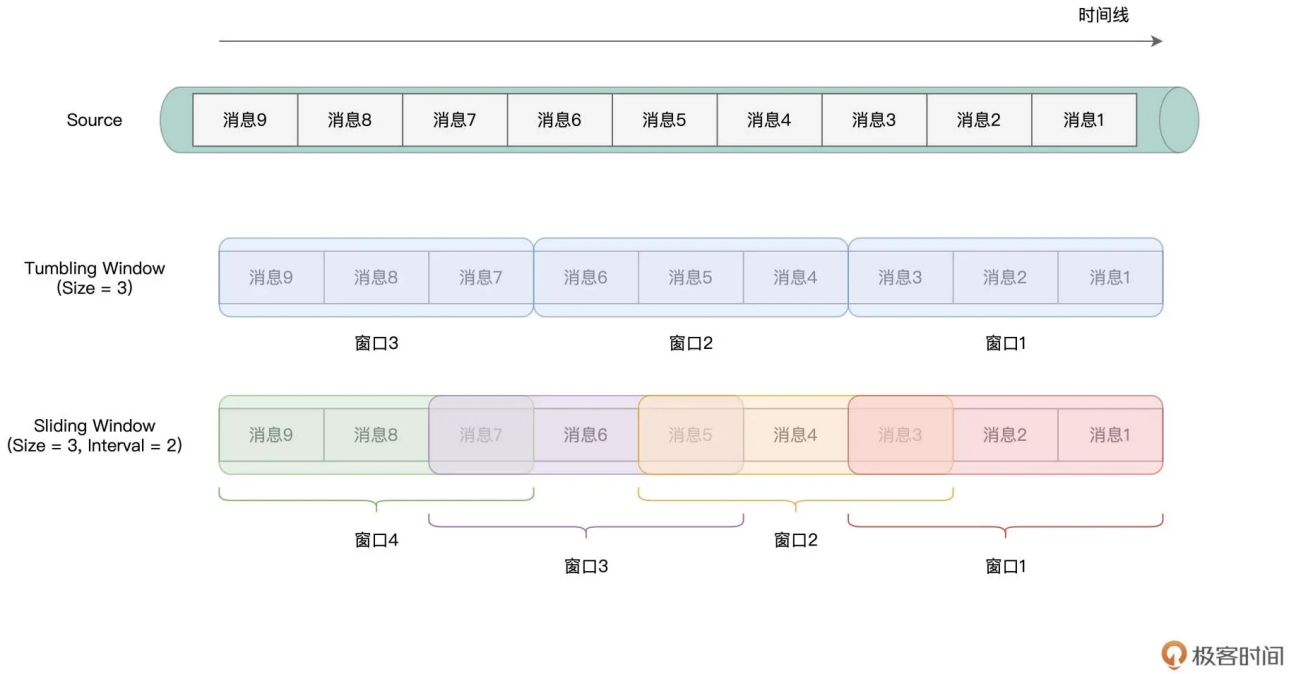

不同的窗口划分方式

不难发现，Sliding Window 划分出来的窗口是否存在“重、漏”，取决于窗口间隔 Interval 与窗口大小 Size 之间的关系。Tumbling Window 与 Sliding Window 并无优劣之分，完全取决于应用场景与业务需要。

干讲理论总是枯燥无趣，接下来，咱们对之前的“流动的 Word Count”稍作调整，来演示 Structured Streaming 中的 Window 操作。为了让演示的过程更加清晰明了，这里我们采用 Tumbling Window 的划分方式，Sliding Window 留给你作为课后作业。

为了完成实验，我们还是需要准备好两个终端。第一个终端用于启动 spark-shell 并提交流处理代码，而第二个终端用于启动 netcat、输入数据流。要基于窗口去统计单词，我们仅需调整数据处理部分的代码，readStream 与 writeStream（Update Mode）部分的代码不需要任何改动。因此，为了聚焦 Window 操作的学习，我这里仅贴出了有所变动的部分。

复制代码

```
df = df.withColumn("inputs", split($"value", ","))
// 提取事件时间
.withColumn("eventTime", element_at(col("inputs"),1).cast("timestamp"))
// 提取单词序列
.withColumn("words", split(element_at(col("inputs"),2), " "))
// 拆分单词
.withColumn("word", explode($"words"))
// 按照Tumbling Window与单词做分组
```

```
9  .groupBy(window(col("eventTime"), "5 minute"), col("word"))
10 // 统计计数
11 .count()
```

为了模拟事件时间，我们在 netcat 终端输入的消息，会同时包含时间戳和单词序列。两者之间以逗号分隔，而单词与单词之间，还是用空格分隔，如下表所示。

行号	内容
1	2021-10-01 09:30:00,Apache Spark
2	2021-10-01 09:34:00,Spark Logo
3	2021-10-01 09:36:00,Structured Streaming
4	2021-10-01 09:39:00,Spark Streaming

极客时间

netcat输入的文本内容

因此，对于输入数据的处理，我们首先要分别提取出时间戳和单词序列，然后再把单词序列展开为单词。接下来，我们按照时间窗口与单词做分组，这里需要我们特别关注这行代码：

复制代码

```
1 // 按照Tumbling Window与单词做分组
2 .groupBy(window(col("eventTime"), "5 minute"), col("word"))
```

其中 window(col(“eventTime”), “5 minute”) 的含义，就是以事件时间为准，以 5 分钟为间隔，创建 Tumbling 时间窗口。显然，window 函数的第一个参数，就是创建窗口所依赖的时间轴，而第二个参数，则指定了窗口大小 Size。说到这里，你可能会问：“如果我想创建 Sliding Window，该怎么做呢？”

其实非常简单，只需要在 window 函数的调用中，再添加第三个参数即可，也就是窗口间隔 Interval。比如说，我们还是想创建大小为 5 分钟的窗口，但是使用以 3 分钟为间隔进行滑动的方式去创建，那么我们就可以这样来实现：window(col(“eventTime”), “5 minute”, “3 minute”)。是不是很简单？

完成基于窗口和单词的分组之后，我们就可以继续调用 count 来完成计数了。不难发现，代码中的大多数转换操作，实际上都是我们常见的 DataFrame 算子，这也印证了这讲开头说的，Structured Streaming 先天优势就是能坐享其成，享有 Spark SQL 提供的“性能红利”。

代码准备好之后，我们就可以把它们陆续敲入到 spark-shell，并等待来自 netcat 的数据流。切换到 netcat 终端，**并陆续（注意，是陆续！）输入刚刚的文本内容**，我们就可以在 spark-shell 终端看到如下的计算结果。

```
-------------------------------------------
Batch: 1
-------------------------------------------
+------------------------------------------+------+-----+
|window                                    |word  |count|
+------------------------------------------+------+-----+
|{2021-10-01 09:30:00, 2021-10-01 09:35:00}|Apache|1    |
|{2021-10-01 09:30:00, 2021-10-01 09:35:00}|Spark |1    |
+------------------------------------------+------+-----+

-------------------------------------------
Batch: 2
-------------------------------------------
+------------------------------------------+-----+-----+
|window                                    |word |count|
+------------------------------------------+-----+-----+
|{2021-10-01 09:30:00, 2021-10-01 09:35:00}|Spark|2    |
|{2021-10-01 09:30:00, 2021-10-01 09:35:00}|Logo |1    |
+------------------------------------------+-----+-----+

-------------------------------------------
Batch: 3
-------------------------------------------
+------------------------------------------+----------+-----+
|window                                    |word      |count|
+------------------------------------------+----------+-----+
|{2021-10-01 09:35:00, 2021-10-01 09:40:00}|Structured|1    |
|{2021-10-01 09:35:00, 2021-10-01 09:40:00}|Streaming |1    |
+------------------------------------------+----------+-----+

-------------------------------------------
Batch: 4
-------------------------------------------
+------------------------------------------+---------+-----+
|window                                    |word     |count|
+------------------------------------------+---------+-----+
|{2021-10-01 09:35:00, 2021-10-01 09:40:00}|Streaming|2    |
|{2021-10-01 09:35:00, 2021-10-01 09:40:00}|Spark    |1    |
+------------------------------------------+---------+-----+
```

执行结果

可以看到，与“流动的 Word Count”不同，这里的统计计数，是以窗口（5 分钟）为粒度的。对于每一个时间窗口来说，Structured Streaming 引擎都会把事件时间落入该窗口的单词统计在内。不难推断，随着时间向前推进，已经计算过的窗口，将不会再有状态上的更新。

比方说，当引擎处理到“2021-10-01 09:39:00,Spark Streaming”这条消息（记作消息 39）时，理论上，前一个窗口“{2021-10-01 09:30:00, 2021-10-01 09:35:00}”（记作窗口 30-35）的状态，也就是不同单词的统计计数，应该不会再有变化。

说到这里，你可能会有这样的疑问：“那不见得啊！如果在消息 39 之后，引擎又接收到一条事件时间落在窗口 30-35 的消息，那该怎么办呢？”要回答这个问题，我们还得从 Late data 和 Structured Streaming 的 Watermark 机制说起。

Late data 与 Watermark

我们先来说 Late data，所谓 Late data，它指的是那些事件时间与处理时间不一致的消息。虽然听上去有点绕，但通过下面的图解，我们就能瞬间理解 Late data 的含义。

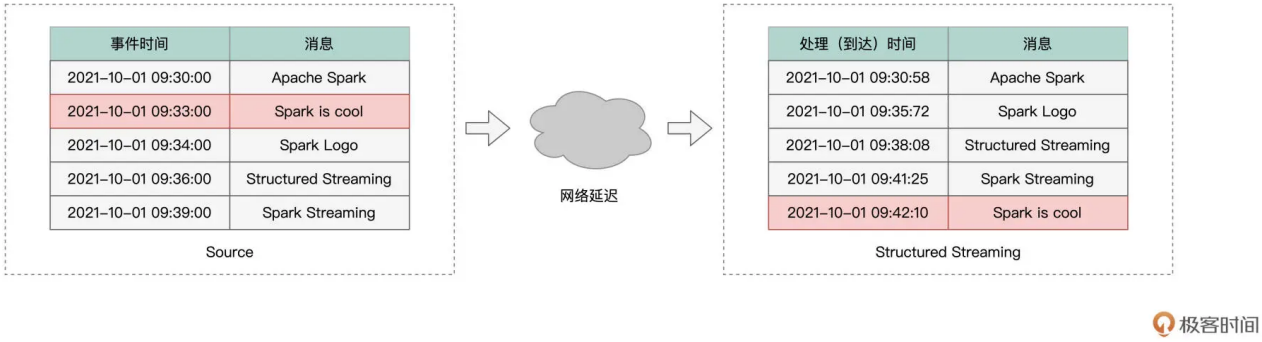

Late data示意图

通常来说，消息生成的时间，与消息到达流处理引擎的时间，应该是一致的。也即先生成的消息先到达，而后生成的消息后到达，就像上图中灰色部分消息所示意的那样。

不过，在现实情况中，总会有一些消息，因为网络延迟或者这样那样的一些原因，它们的处理时间与事件时间存在着比较大的偏差。这些消息到达引擎的时间，甚至晚于那些在它们之后才生成的消息。像这样的消息，我们统称为“Late data”，如图中红色部分的消息所示。

由于有 Late data 的存在，流处理引擎就需要一个机制，来判定 Late data 的有效性，从而决定是否让晚到的消息，参与到之前窗口的计算。

就拿红色的“Spark is cool”消息来说，在它到达 Structured Streaming 引擎的时候，属于它的事件时间窗口“{2021-10-01 09:30:00, 2021-10-01 09:35:00}”已经关闭了。

那么，在这种情况下，Structured Streaming 到底要不要用消息“Spark is cool”中的单词，去更新窗口 30-35 的状态（单词计数）呢？

为了解决 Late data 的问题，Structured Streaming 采用了一种叫作 Watermark 的机制来应对。为了让你能够更容易地理解 Watermark 机制的原理，在去探讨它之前，我们先来澄清两个极其相似但是又完全不同的概念：水印和水位线。

要说清楚水印和水位线，咱们不妨来做个思想实验。假设桌子上有一盒鲜牛奶、一个吸管、还有一个玻璃杯。我们把盒子开个口，把牛奶全部倒入玻璃杯，接着，把吸管插入玻璃杯，然后通过吸管喝一口新鲜美味的牛奶。好啦，实验做完了，接下来，我们用它来帮我们澄清概念。

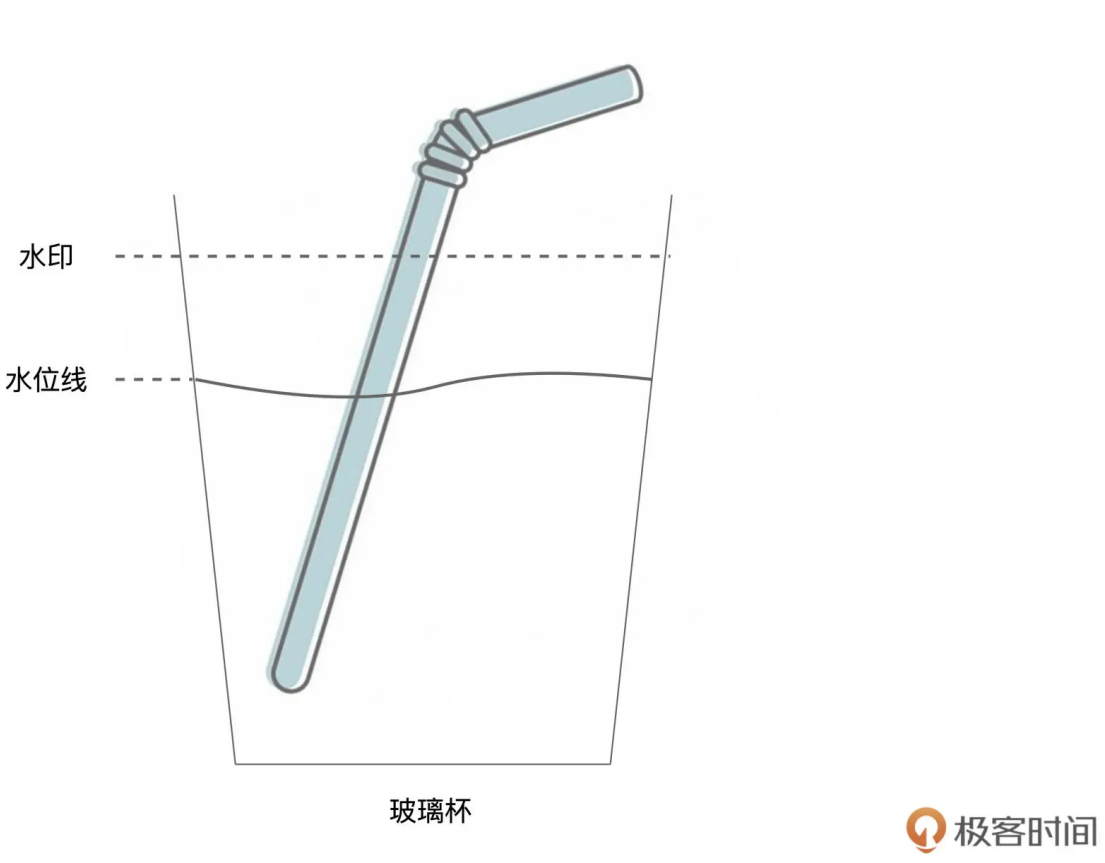

水印、水位线示意图

如图所示，最开始的时候，我们把牛奶倒到水印标示出来的高度，然后用吸管喝牛奶。不过，不论我们通过吸管喝多少牛奶，水印位置的牛奶痕迹都不会消失，也就是说，水印的位置是相对固定的。而水位线则不同，我们喝得越多，水位线下降得就越快，直到把牛奶喝光，水位线降低到玻璃杯底部。

好啦，澄清了水印与水位线的概念之后，我们还需要把这两个概念与流处理中的概念对应上。毕竟，“倒牛奶”的思想实验，是用来辅助我们学习 Watermark 机制的。

首先，水印与水位线，对标的都是消息的事件时间。水印相当于系统当前接收到的所有消息中最大的事件时间。而水位线指的是水印对应的事件时间，减去用户设置的容忍值。为了叙述方便，我们把这个容忍值记作 T。在 Structured Streaming 中，我们把水位线对应的事件时间，称作 Watermark，如下图所示。

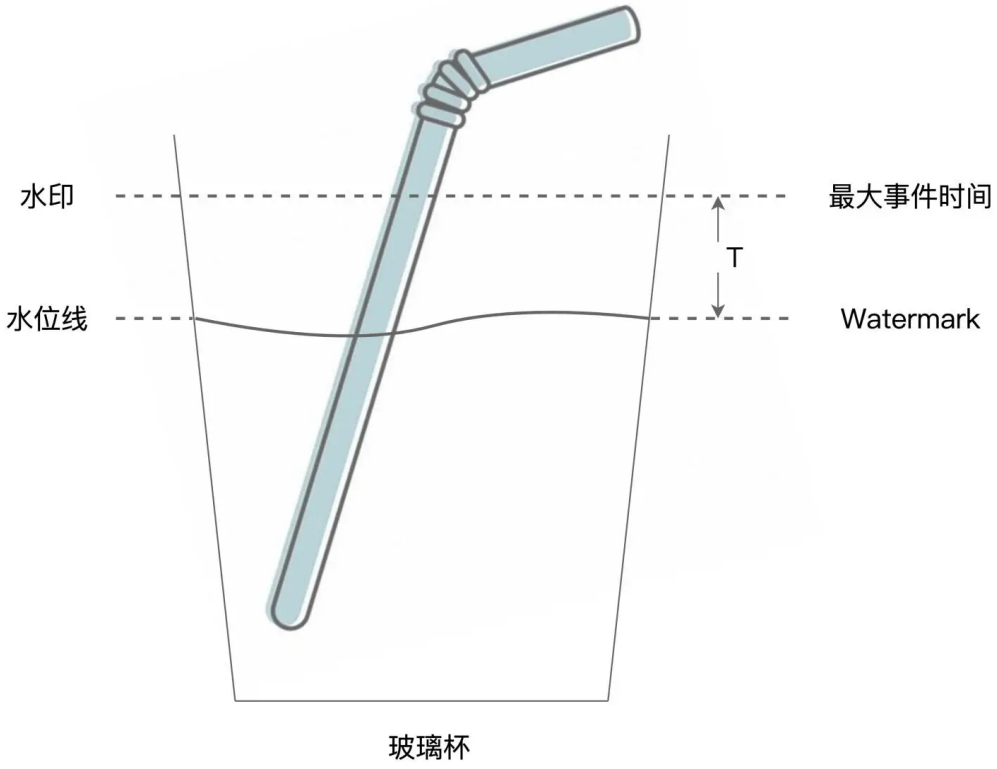

极客时间

概念之间的对应关系

显然，在流处理引擎不停地接收消息的过程中，水印与水位线也会相应地跟着变化。这个过程，跟我们刚刚操作的“倒牛奶、喝牛奶”的过程很像。每当新到消息的事件时间大于当前水印的时候，系统就会更新水印，这就好比我们往玻璃杯里倒牛奶，一直倒到最大事件时间的位置。然后，我们用吸管喝牛奶，吸掉深度为 T 的牛奶，让水位线下降到 Watermark 的位置。

把不同的概念关联上之后，接下来，我们来正式地介绍 Structured Streaming 的 Watermark 机制。我们刚刚说过，Watermark 机制是用来决定，哪些 Late data 可以参

与过往窗口状态的更新，而哪些 Late data 则惨遭抛弃。

如果用文字去解释 Watermark 机制，很容易把人说得云里雾里，因此，咱们不妨用一张流程图，来阐释这个过程。

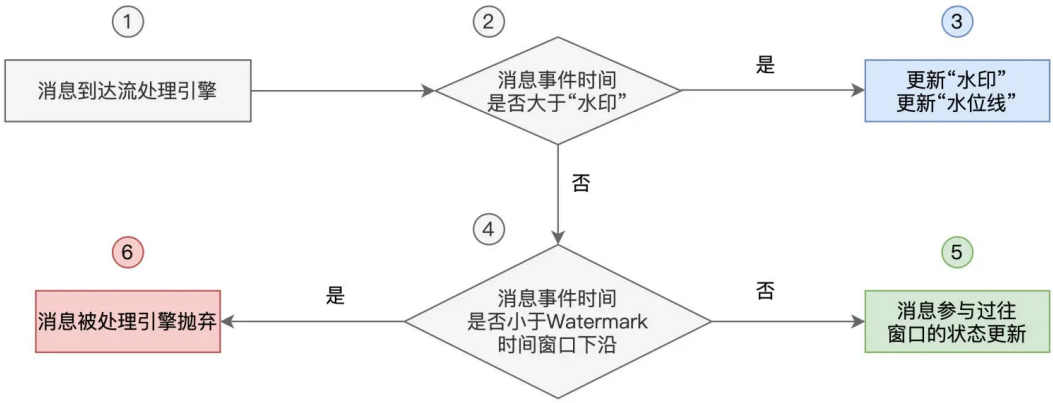

Watermark机制

可以看到，当有新消息到达系统后，Structured Streaming 首先判断它的事件时间，是否大于水印。如果事件时间大于水印的话，Watermark 机制则相应地更新水印与水位线，也就是最大事件时间与 Watermark。

相反，假设新到消息的事件时间在当前水印以下，那么系统进一步判断消息的事件时间与“Watermark 时间窗口下沿”的关系。所谓“Watermark 时间窗口下沿”，它指的是 Watermark 所属时间窗口的起始时间。

咱们来举例说明，假设 Watermark 为“2021-10-01 09:34:00”，且事件时间窗口大小为 5 分钟，那么，Watermark 所在时间窗口就是[“2021-10-01 09:30:00”，“2021-10-01 09:35:00”]，也即窗口 30-35。这个时候，“Watermark 时间窗口下沿”，就是窗口 30-35 的起始时间，也就是“2021-10-01 09:30:00”，如下图所示。

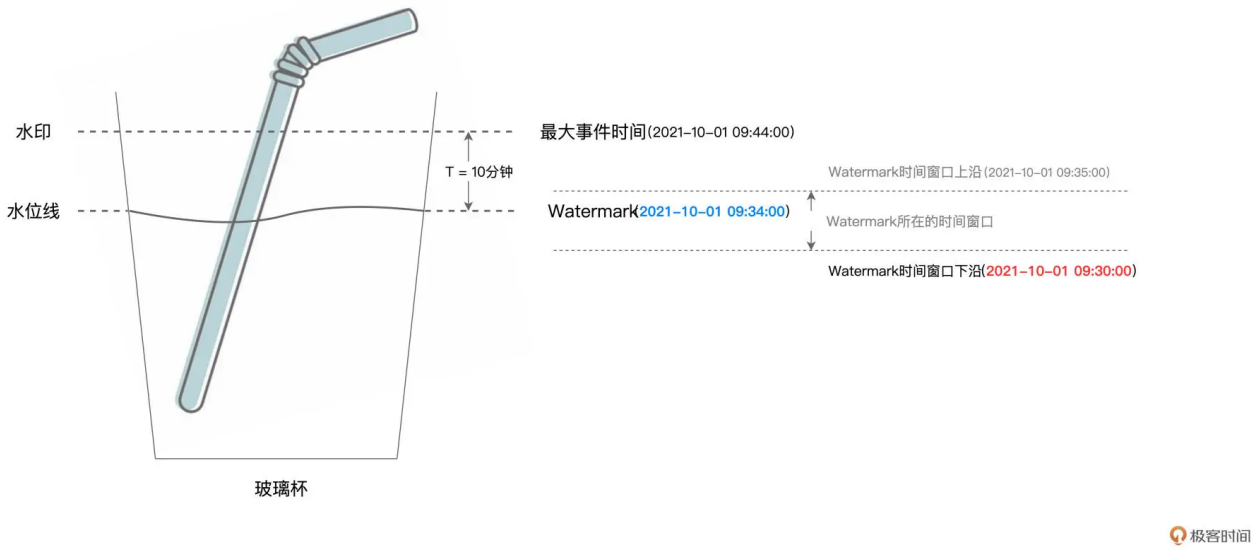

示意图：Watermark时间窗口下沿

对于最新到达的消息，如果其事件时间大于“Watermark 时间窗口下沿”，则消息可以参与过往窗口的状态更新，否则，消息将被系统抛弃，不再参与计算。换句话说，凡是事件时间小于“Watermark 时间窗口下沿”的消息，系统都认为这样的消息来得太迟了，没有资格再去更新以往计算过的窗口。

不难发现，在这个过程中，**延迟容忍度 T 是 Watermark 机制中的决定性因素**，它决定了“多迟”的消息可以被系统容忍并接受。那么问题来了，既然 T 是由用户设定的，那么用户通过什么途径来设定这个 T 呢？再者，在 Structured Streaming 的开发框架下，Watermark 机制要如何生效呢？

其实，要开启 Watermark 机制、并设置容忍度 T，我们只需一行代码即可搞定。接下来，我们就以刚刚“带窗口的流动 Word Count”为例，演示并说明 Watermark 机制的具体用法。

复制代码

```
df = df.withColumn("inputs", split($"value", ","))
// 提取事件时间
.withColumn("eventTime", element_at(col("inputs"),1).cast("timestamp"))
// 提取单词序列
.withColumn("words", split(element_at(col("inputs"),2), " "))
// 拆分单词
.withColumn("word", explode($"words"))
// 启用Watermark机制，指定容忍度T为10分钟
.withWatermark("eventTime", "10 minute")
// 按照Tumbling Window与单词做分组
.groupBy(window(col("eventTime"), "5 minute"), col("word"))
```

```
12 // 统计计数
13 .count()
```

可以看到，除了“.withWatermark(“eventTime”，“10 minute”)”这一句代码，其他部分与“带窗口的流动 Word Count”都是一样的。这里我们用 withWatermark 函数来启用 Watermark 机制，该函数有两个参数，第一个参数是事件时间，而第二个参数就是由用户指定的容忍度 T。

为了演示 Watermark 机制产生的效果，接下来，咱们对 netcat 输入的数据流做一些调整，如下表所示。注意，消息 7“Test Test”和消息 8“Spark is cool”都是 Late data。

行号	内容	所属的事件时间窗口
1	2021-10-01 09:30:00,Apache Spark	窗口30-35
2	2021-10-01 09:34:00,Spark Logo	
3	2021-10-01 09:36:00,Structured Streaming	窗口35-40
4	2021-10-01 09:39:00,Spark Streaming	
5	2021-10-01 09:41:00,AMP Lab	窗口40-45
6	2021-10-01 09:44:00,Spark SQL	
7	2021-10-01 09:29:00,Test Test	窗口25-30
8	2021-10-01 09:33:00,Spark is cool	窗口30-35

极客时间

调整netcat输入的文本内容

基于我们刚刚对于 Watermark 机制的分析，在容忍度 T 为 10 分钟的情况下，Late data 消息 8“Spark is cool”会被系统接受并消费，而消息 7“Test Test”则将惨遭抛弃。你不妨先花点时间，自行推断出这一结论，然后再来看后面的结果演示。

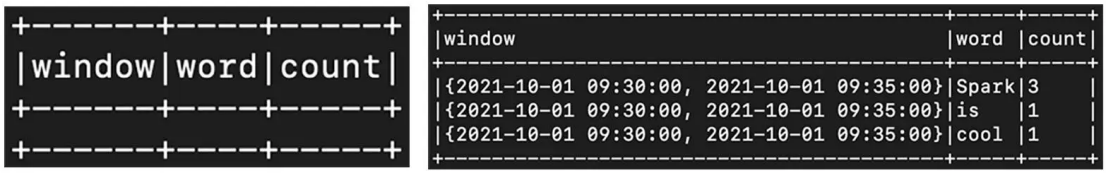

Watermark机制演示：（左）消息7被丢弃、（右）消息8被接受

上图中，左侧是输入消息 7“Test Test”时 spark-shell 端的输出，可以看到，消息 7 被系统丢弃，没能参与计算。而右侧是消息 8“Spark is cool”对应的执行结果，可以看到，“Spark”、“is”、“cool”这 3 个单词成功地更新了之前窗口 30-35 的状态（注意这里的“Spark”计数为 3，而不是 1）。

重点回顾

好啦，今天的内容，到这里就讲完了，我们一起来做个总结。首先，我们需要知道，在数据处理方面，Structured Streaming 完全可以复用 Spark SQL 现有的功能与性能优势。因此，开发者完全可以“坐享其成”，使用 DataFrame 算子或是 SQL 语句，来完成流数据的处理。

再者，我们需要特别关注并掌握 Structured Streaming 的 Window 操作与 Watermark 机制。Structured Streaming 支持两类窗口，**一个是“不重不漏”的 Tumbling Window，另一个是“可重可漏”的 Sliding Window。**二者并无高下之分，作为开发者，我们可以使用 window 函数，结合事件时间、窗口大小、窗口间隔等多个参数，来灵活地在两种窗口之间进行取舍。

对于 Late data 的处理，Structured Streaming 使用 Watermark 机制来决定其是否参与过往窗口的计算与更新。关于 Watermark 机制的工作原理，我把它整理到了下面的流程图中，供你随时查看。

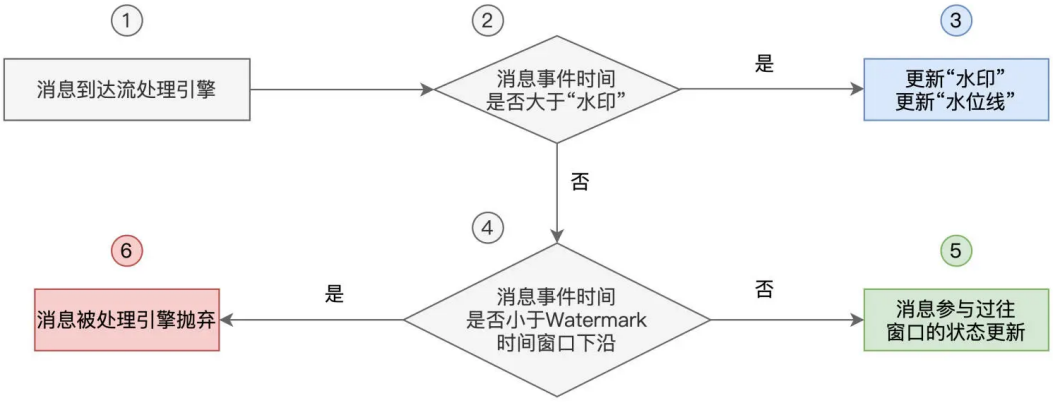

极客时间

Watermark机制

每课一练

1. 请你结合 Tumbling Window 的代码，把 Tumbling Window 改为 Sliding Window。

2. 对于 Watermark 机制中的示例，请你分析一下，为什么消息 8“Spark is cool”会被系统接受并处理，而消息 7“Test Test”却惨遭抛弃？

欢迎你在留言区跟我交流讨论，也推荐你把这一讲分享给更多同事、朋友。

分享给需要的人，Ta订阅后你可得 20 元现金奖励

生成海报并分享

赞 0 提建议

© 版权归极客邦科技所有，未经许可不得传播售卖。 页面已增加防盗追踪，如有侵权极客邦将依法追究其法律责任。

上一篇 31 | 新一代流处理框架：Batch mode和Continuous mode哪家强？

下一篇 33 | 流计算中的数据关联：流与流、流与批

更多学习推荐

2021 最新大厂
Go 工程师面试真题

大厂面试真题 + 金九银十全新整理 + 核心知识全覆盖

免费领取

精选留言

写留言

> 由作者筛选后的优质留言将会公开显示，欢迎踊跃留言。